

階層的グラフニューラルネットワークを用いたドロップアウト予測

Hierarchical Graph Neural Networks for Student Dropout Prediction

淵本 壱真^{*1}, 和田 爽花^{*1}, 植野 真臣^{*1}
Kazuma FUCHIMOTO^{*1}, Sawaka WADA^{*1}, Maomi UENO^{*1}

^{*1} 電気通信大学 情報理工学研究科

^{*1} Graduate School of Informatics and Engineering, The University of Electro-Communications
Email: fuchimoto@ai.lab.uec.ac.jp

あらまし: ドロップアウト予測とは、ある単位を落単する確率を予測することである。ドロップアウト予測では、リスクのある学生を早期に特定し、適切な学習支援を行うため、予測精度と解釈性の両立が求められる。本研究では、入学時学力調査の結果を特徴量として、問題特性を活用した階層的グラフニューラルネットワークによるドロップアウト予測手法を提案する。この結果、提案手法は、従来よりも予測精度を向上し、解釈性を持つことを示す。

キーワード: ドロップアウト予測, グラフニューラルネットワーク, CBT, パフォーマンス予測

1. はじめに

ドロップアウト予測とは、教育機関においてある学生が単位を取得できない可能性を予測することである。ドロップアウトは、その後の学習成果、精神状態、および進路に悪影響を及ぼすため、リスクのある学生を早期に予測し、教育機関が適切に支援することが重要である⁽¹⁾。

近年、機械学習分野の発展により、様々なドロップアウト予測の手法が研究されている^(2,3)。しかし、これらの手法は解釈性と予測精度の両立ができず、実応用には限界がある。

この問題を解決するために、本研究では、解釈性と予測精度を両立する階層的グラフニューラルネットワーク(GNN)⁽⁴⁾を用いたドロップアウト予測手法を提案する。入学時学力調査(数学)で得られた正誤データから入学後の数学科目のドロップアウト予測を行う。学力調査で用いられた問題項目には、分野や教科が階層的にラベル付けされている。提案手法では、この階層構造を段階的なGNNで構成することで解釈性と予測精度を両立する。

実データ実験の結果、提案手法は従来手法よりもドロップアウト予測の精度が向上した。さらに、提案手法は、GNNのグラフ構造を分析し、ドロップアウト予測に寄与した分野やその分野間の関連性を解釈できることを示した。

2. 提案手法

提案手法では、入学時学力調査(数学)で得られた正誤データから入学後の数学科目のドロップアウト予測を行う。学力調査で出題された各問題項目には分野や教科が階層的にラベル付けされている。例えば、分野は「微分」、「積分」など、教科は「数I」、「数A」など高校生の学習指導要領に従ってラベル付けされている。提案手法では、この階層構造を利用したGNNによるドロップアウト予測を行う。

図1は提案手法のモデル図である。はじめに、提

案手法ではラベル付けされた分野ごとに、正誤データから問題項目GNNを構築する。この問題項目グラフからDiffpool⁽⁵⁾を用いて、各頂点が各分野の特徴量を持つ分野GNNに縮約する。ここで、Diffpoolとは、クラスタ割り当て行列を用いて、グラフ構造と特徴量を段階的にソフトクラスタリングする手法である。Diffpoolではクラスタ割り当て行列から縮約後のグラフや予測に影響を与えた特徴量を解釈できる。したがって、その単位取得に必要な分野や教科の分析ができるため、リスクのある学生に適切な支援が可能となる。

さらに、提案手法では、分野にラベル付けされた教科ごとに、Diffpool⁽⁵⁾を用いて、各頂点が各教科の特徴量を持つ教科GNNに縮約する。その後、提案手法では、この教科GNNをGraph Attention Networks⁽⁶⁾とDiffpoolに入力して得られた特徴量からドロップアウト予測を行う。これにより、提案手法では、問題項目と分野の階層構造を利用したGNNにより得られた特徴量からドロップアウト予測を行う。

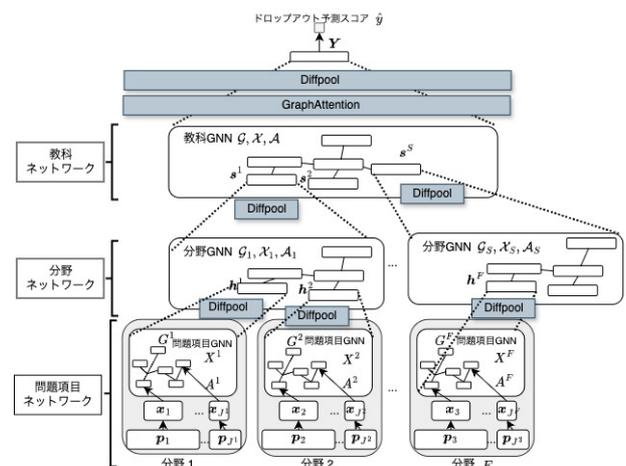


図1 提案手法のモデル図

表1 各手法の AUC

科目	提案 (分野)	提案 (教科)	GNN	DNN	XGB	LGBM
微積1	0.723 (0.071)	0.697 (0.064)	0.697 (0.064)	0.684 (0.071)	0.677 (0.035)	0.677 (0.032)
微積2	0.675 (0.030)	0.669 (0.026)	0.669 (0.027)	0.650 (0.028)	0.592 (0.034)	0.598 (0.023)
線形1	0.679 (0.036)	0.674 (0.031)	0.674 (0.032)	0.644 (0.048)	0.664 (0.066)	0.667 (0.075)
線形2	0.637 (0.037)	0.632 (0.039)	0.632 (0.039)	0.611 (0.026)	0.610 (0.033)	0.601 (0.018)
数演1	0.709 (0.041)	0.700 (0.038)	0.700 (0.039)	0.712 (0.032)	0.644 (0.037)	0.653 (0.035)
数演2	0.729 (0.065)	0.716 (0.057)	0.729 (0.042)	0.717 (0.067)	0.644 (0.059)	0.643 (0.047)
解析学	0.693 (0.052)	0.690 (0.042)	0.716 (0.057)	0.689 (0.035)	0.635 (0.062)	0.637 (0.060)
平均	0.692 (0.047)	0.683 (0.042)	0.683 (0.042)	0.672 (0.043)	0.638 (0.046)	0.639 (0.041)

3. 評価実験

評価実験では、本学の入学時学力調査における数学 CBT 試験の各問題への正誤反応データを用いる。この学力調査は 666 人が受検し、18 分野 6 教科から全 141 問題項目が出題された。このデータから各学生が 1 年時に受講した数学系科目 7 つ（微積 1・2、線形代数 1・2、数学演習 1・2、解析学）に対してドロップアウト予測を行った。ただし、本研究では、可または不可を取得した学生をドロップアウトとした。

結果を表 1 に示す。提案(分野)と(教科)はそれぞれ階層構造を分野 GNN, 教科 GNN(図 1)まで構成した場合を示す。提案(分野)は数学演習第一を除く全科目で最も高い AUC を示した。また、全科目の平均 AUC も従来手法より良い値を示した。特に、階層構造を考えない GNN と比較して、予測精度が向上した。そのため、本研究のように、明示的な階層構造を GNN で学習することは、モデルの解釈性を高めるとともに、予測精度の向上にも寄与した。

一方で、提案(教科)は予測精度でわずかに提案(分野)より精度が悪化した。したがって、過度に複雑なラベル付けや階層構造は予測精度に悪い影響を与えることを示している。

次に、提案手法のドロップアウト予測に寄与した分野を解析するために、分野グラフの縮約に用いたクラスタ割り当て行列を分析する。この行列を分析することで、各科目のドロップアウトにどの分野がどの程度影響するか可視化できる⁽⁵⁾。

図 2 に結果を示す。図 2 は数学 7 科目について得られたクラスタ割り当て行列のヒートマップである。具体的には、縦軸は分野、横軸はドロップアウト予測を行った科目を示す。また、ヒートマップの色が黄色に近い(行列の値が大きい)ほど、その科目のドロップアウト予測における分野の影響が強いことを示す。この図から、全ての科目において、「積分法」がドロップアウト予測に最も大きな影響を与えることが分かる。

微積1 線形1 数演1 微積2 線形2 数演2 解析学

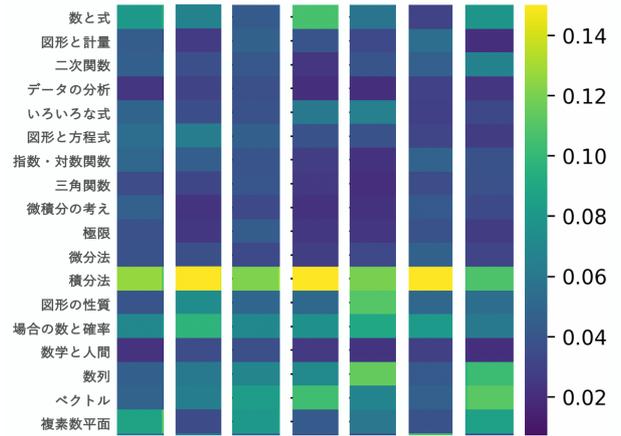


図 2 各科目のドロップアウト予測の要因分析

一方で、「微分法」は微積のドロップアウト予測でさえ、ほとんど影響を与えておらず、興味深い結果を示した。

以上のように、提案手法はドロップアウト予測に寄与した要因を解釈することで、リスクのある学生へ学習内容を考慮した適切な支援ができる。

4. むすび

本研究では階層的グラフニューラルネットワークを用いたドロップアウト予測手法を提案した。実データ実験の結果、提案手法は従来手法よりも解釈性を向上し、ドロップアウト予測精度も向上した。

今後は、個々の学生がドロップアウト予測に影響を与える要因を分析できる手法への拡張を目指す。

参考文献

- (1) Rola Ajjawi, N. Z. S. B., Mary Dracup and Boud, D.: Persisting students' explanations of and emotional responses to academic failure, Higher Education Research & Development, Vol. 39, No. 2, pp. 185-199 (2020).
- (2) Chen, T. and Guestrin, C.: XGBoost: A Scalable Tree Boosting System. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16), 785-794, (2016).
- (3) Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., and Liu, T. Y.: LightGBM: A highly efficient gradient boosting decision tree, in Advances in Neural Information Processing Systems, Vol. 30 (2017).
- (4) Scarselli, F., Gori, M., Ah Chung Tsoi, Hagenbuchner, M., and Monfardini, G.: The Graph Neural Network Model, IEEE Transactions on Neural Networks, Vol. 20, No. 1, pp. 61-80, (2009).
- (5) Ying, R., You, J., Morris, C., Ren, X., Hamilton, W. L., and Leskovec, J.: Hierarchical Graph Representation Learning with Differentiable Pooling, In Proceedings of the 32nd International Conference on Neural Information Processing Systems (NIPS'18), pp. 4805-4815, (2018).
- (6) Veličković, P., Cucurull, G., Casanova, A., Romero, A., Liò, P., and Bengio, Y.: Graph Attention Networks, in ICLR 2018, (2018).